

**Klasifikasi Kematangan Sawit Menggunakan Metode
*Convolutional Neural Network (CNN) Dengan Transfer Learning
Xception***

*Imam Afandy, Bahauddin Nafis Ahmad, Muhammad Rafly Amartharizqi
Universitas Pembangunan Nasional "Veteran" Jawa Timur, Indonesia

Artikel Histori:

Disubmit: Juli 2024
Diterima: September 2024
Diterbitkan: Desember 2024

DOI

[10.33005/jifti.v6i2.158](https://doi.org/10.33005/jifti.v6i2.158)



ABSTRAK

Penelitian ini membahas implementasi metode Deep Learning menggunakan algoritma Xception dengan augmentasi data untuk klasifikasi tingkat kematangan buah kelapa sawit. Dataset yang digunakan terdiri dari 613 citra sawit yang diperoleh dari Kaggle. Data tersebut memiliki dua kelas, yaitu matang dan belum matang. Data yang diperoleh diperkaya melalui teknik augmentasi seperti flipping, zooming, dan penyesuaian pencahayaan. Penelitian ini menggunakan arsitektur Xception, yang memanfaatkan deptwise separable convolution untuk meningkatkan efisiensi komputasi dan akurasi dalam ekstraksi fitur. Preprocessing data meliputi rescaling pixel dan penyesuaian ukuran gambar menjadi 299 x 299 piksel, sesuai standar Xception. Model dilatih menggunakan optimizer Adam dengan pembagian data latih dan uji sebesar 85:15. Hasil menunjukkan dengan teknik augmentasi data dan arsitektur Xception hasil kinerja model memperoleh tingkat akurasi sebesar 90%. Studi ini memberikan kontribusi dalam pengembangan sistem klasifikasi otomatis berbasis citra, yang dapat mendukung efisiensi dalam industri kelapa sawit.

Kata Kunci: Deep Learning, Xception, Augmentasi data, Klasifikasi Kematangan Sawit.

How to Cite:

Afandy, I., Ahmad, B. N., Amartharizqi, M. R. (2024). Klasifikasi Kematangan Sawit Menggunakan Metode *Convolutional Neural Network (CNN) Dengan Transfer Learning Xception*. *Jurnal Ilmiah Teknologi Informasi dan Robotika*, 6(2), 88-98. <https://doi.org/10.33005/jifti.v6i2.158>.

***Corresponding Author:**

Email : 21081010290@student.upnjatim.ac.id
Alamat : Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. anyar,
Surabaya, Jawa Timur, 60294



This article is published under a Creative Commons Attribution 4.0 International License.

PENDAHULUAN

Sektor perkebunan menjadi zandalan perekonomian Indonesia, memberikan kontribusi sebesar 96,86% dari total ekspor pertanian, dengan 73,83% di antaranya berasal dari kelapa sawit (Fevriera dkk, 2023). Hal ini menjadikan kelapa sawit memiliki peranan yang sangat penting bagi Indonesia, terutama sebagai negara penghasil dan pengeksport minyak kelapa sawit terbesar di dunia (Siswanto, 2020). Komoditas ini memproduksi *Crude Palm Oil* (CPO), nantinya CPO digunakan untuk memproduksi kosmetik, bahan baku pangan dan bahan bakar biodiesel. Menurut Badan Pusat Statistik pada tahun 2023 terdapat 47 juta ton CPO yang dihasilkan dari kelapa sawit (B. Indonesia, 2024). Produksi CPO dipengaruhi oleh dua faktor utama, pertama tingkat ekstraksi minyak di pabrik kelapa sawit dan kedua yaitu kandungan minyak yang terdapat pada tandan buah segar (Murgianto dkk, 2021). Buah kelapa sawit yang matang optimal merupakan syarat utama untuk menghasilkan CPO berkualitas tinggi. Indikator kematangan buah dapat dilihat dari perubahan warnanya menjadi kuning kemerahan (Murgianto dkk, 2021). Tingkat kematangan memiliki hubungan linear dengan hasil CPO - semakin matang buahnya, semakin tinggi pula rendemen CPO yang diperoleh. Selain itu, fase kematangan buah juga berperan penting dalam menentukan konsentrasi senyawa-senyawa bermanfaat seperti tokol dan beta karoten (Akbar dkk, 2023).

Identifikasi tingkat kematangan kelapa sawit saat ini masih bertumpu pada pengamatan visual oleh pekerja. Tantangan timbul dalam membedakan beberapa fase kematangan yang memiliki ciri-ciri mirip. Hal ini berpotensi mempengaruhi optimalisasi hasil produksi kelapa sawit secara keseluruhan. Efisiensi produksi dan kualitas produk dapat dipertahankan melalui sistem klasifikasi yang tepat dalam mengelompokkan hasil kelapa sawit berdasarkan standar mutunya. Strategi peningkatan kualitas produk dapat dilakukan melalui penerapan teknologi *Machine Learning* menggunakan algoritma *Xception*, yang memungkinkan pengelompokan produk kelapa sawit secara lebih efektif.

Algoritma *Xception*, yang merupakan singkatan dari "*Extreme version of Inception*", adalah salah satu metode yang dikembangkan dalam bidang *deep learning* (Masaugi, 2024). Pada penelitian yang dilakukan Francois Chollet model yang menggunakan *Xception* memiliki akurasi tertinggi sebesar 94,5% (Avery dkk, 2014). Penelitian lain yang menggunakan *Xception* pada klasifikasi citra tanaman minyak atsiri menunjukkan bahwa model dapat mencapai akurasi pelatihan sebesar 93% dan validasi sebesar 77% hanya dengan 5 epoch (Carnegie dkk, 2022)

Pada saat melakukan pelatihan data dibutuhkan augmentasi data untuk menghindari masalah *overfitting* (Rizki dkk, 2023). Augmentasi bertujuan untuk meningkatkan variasi data sekaligus memperkuat kemampuan generalisasi model *deep learning* (Chan dkk, 2023). Pada data citra yang telah kami dapatkan ditemukan data citra yang tidak seimbang antara kelas matang dan belum matang.

Berdasarkan latar belakang yang telah dijabarkan kami menggunakan algoritma *Xception* dipilih untuk klasifikasi tingkat kematangan buah kelapa sawit karena kemampuannya yang telah terbukti dalam mengatasi tugas klasifikasi citra dengan tingkat akurasi yang tinggi. Penelitian ini bertujuan untuk mengembangkan model klasifikasi yang efektif dalam mengidentifikasi kematangan buah kelapa sawit, yang pada gilirannya dapat meningkatkan efisiensi dan kualitas produksi CPO.

Dalam penelitian ini, data citra buah kelapa sawit yang telah dikumpulkan akan menjalani proses pengolahan awal, termasuk augmentasi untuk mengatasi masalah ketidakseimbangan kelas. Proses augmentasi ini bertujuan untuk memperluas variasi data tanpa perlu mengumpulkan data tambahan secara fisik. Setelah itu, model Xception akan dilatih menggunakan dataset tersebut, dengan penekanan pada optimalisasi parameter model guna meningkatkan akurasi klasifikasi.

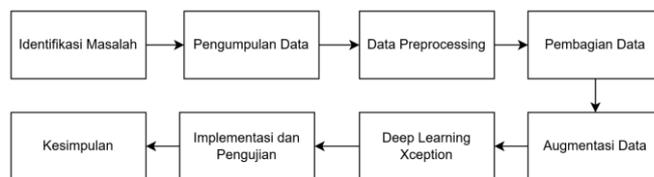
Diharapkan hasil dari penelitian ini akan menghasilkan model yang mampu secara otomatis mengelompokkan buah kelapa sawit ke dalam kategori matang dan belum matang dengan tingkat akurasi yang tinggi. Penerapan model ini tidak hanya akan membantu pekerja dalam mengidentifikasi kematangan buah dengan lebih konsisten, tetapi juga berkontribusi pada peningkatan produktivitas dan kualitas industri kelapa sawit di Indonesia.

METODE PENELITIAN

Penelitian ini dilaksanakan melalui serangkaian tahapan yang terstruktur dan saling berkaitan. Dimulai dengan identifikasi masalah, peneliti menentukan fokus penelitian, melakukan tinjauan literatur, dan merumuskan pertanyaan atau hipotesis yang akan dijawab. Selanjutnya, tahap pengumpulan data melibatkan penentuan sumber data yang relevan dan pelaksanaan metode pengumpulan yang telah dirancang. Data yang terkumpul kemudian memasuki tahap data preprocessing, di mana dilakukan pembersihan, penanganan *missing values* dan *outliers*, serta transformasi data agar sesuai dengan kebutuhan analisis. Setelah itu, data yang telah diproses dibagi menjadi beberapa subset, yaitu training set dan validation set untuk memastikan evaluasi model yang adil dan representatif. Pada subset training set, dilakukan augmentasi data guna meningkatkan variasi dataset, sehingga model dapat lebih robust dan mampu melakukan generalisasi dengan baik pada data baru. Tahap krusial berikutnya adalah penerapan deep learning menggunakan model Xception, yang mencakup persiapan dataset, konfigurasi model, pelatihan, dan evaluasi performa. Setelah model dioptimalkan, tahap implementasi dan pengujian dilakukan untuk memastikan model berfungsi dengan baik dalam lingkungan nyata. Akhirnya, penelitian diakhiri dengan penarikan kesimpulan, di mana hasil dianalisis secara menyeluruh, kontribusi penelitian dievaluasi, dan rekomendasi untuk penelitian lanjutan dirumuskan. Detail tahapan alur metodologi terdapat pada Gambar 1.

Pengumpulan Data

Pada tahap ini, penelitian memanfaatkan dataset yang tersedia di Kaggle (<https://www.kaggle.com/datasets/ahmadfathan/kematangansawit>), yang terdiri dari citra buah sawit yang diambil menggunakan kamera ponsel. Foto-foto tersebut mencakup buah sawit yang masih di pohon maupun yang telah dipanen. Dataset ini dikelompokkan ke dalam dua kategori utama: buah sawit matang dan belum matang, dengan total 613 gambar, di mana 516 gambar termasuk kategori matang, dan 97 gambar termasuk kategori belum matang. Selain memanfaatkan dataset dari Kaggle, penelitian ini juga memperluas jumlah dan variasi data dengan menerapkan teknik augmentasi, seperti flipping, untuk menciptakan citra baru yang dapat meningkatkan keragaman dan kualitas dataset. Pendekatan ini bertujuan untuk memperkaya data pelatihan sehingga model dapat lebih efektif dalam mengenali pola dan meningkatkan akurasi klasifikasi.



Gambar 1. Alur metodologi

Sumber: Data Diolah

$$Rescale = \frac{piksel}{255}$$

Gambar 2. Rumus *rescale*

Sumber: Data Diolah

Preprocessing Data

Tahap preprocessing citra meliputi rescaling nilai piksel dari 0-255 menjadi 0-1 untuk menormalkan skala fitur, meningkatkan stabilitas numerik, dan mempercepat konvergensi model. Selain itu, ukuran citra disesuaikan menjadi 299x299 piksel sesuai standar Xception untuk memastikan konsistensi data, efisiensi memori, dan kompatibilitas dengan bobot pra-pelatihan dari ImageNet. Metode interpolasi seperti bilinear atau bicubic digunakan untuk resizing, dengan bilinear memberikan keseimbangan antara kualitas dan kecepatan. Kombinasi rescaling dan resizing mempersiapkan data input secara optimal, memungkinkan model bekerja lebih efisien dan meningkatkan akurasi tugas klasifikasi.

Augmentasi Data

Augmentasi data digunakan untuk memperkaya dataset citra sawit, terutama kategori buah mentah yang jumlahnya lebih sedikit dibandingkan buah matang. Teknik yang diterapkan meliputi flip vertikal dan horizontal, gaussian blur, brightness adjustment, contrast adjustment, zooming, dan noise injection, untuk menciptakan variasi tanpa mengubah karakteristik citra. Hasilnya, jumlah data sawit mentah meningkat dari 97 menjadi 528 gambar, membuat dataset lebih seimbang. Proses ini dilakukan otomatis menggunakan Google Colab dan library Augmentor, memanfaatkan GPU untuk efisiensi. Augmentasi membantu memperbesar dataset, meningkatkan variasi, mengurangi overfitting, dan menyeimbangkan distribusi kelas. Model deep learning yang dilatih diharapkan lebih akurat dalam mengenali buah sawit matang dan mentah di berbagai kondisi.

Pembagian Data

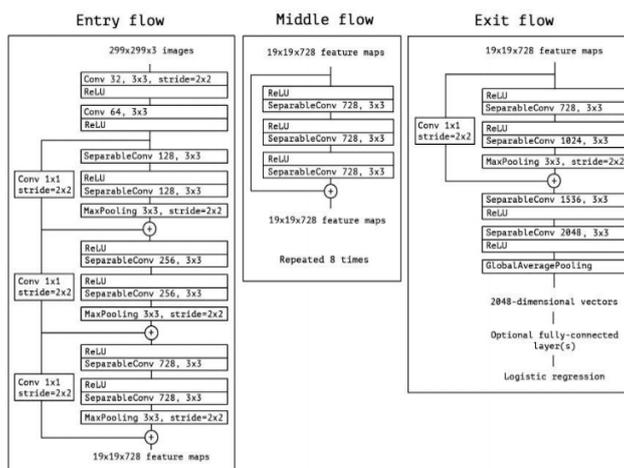
Pada penelitian ini, dataset citra kelapa sawit dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*testing data*). Data latih digunakan untuk melatih model dalam mengenali pola dan fitur pada citra kelapa sawit, sedangkan data uji digunakan untuk mengukur performa model dalam mengklasifikasikan data yang belum pernah dilihat sebelumnya. Pembagian data dilakukan secara terpisah untuk memastikan validitas evaluasi model. Dataset awal terdiri dari 442 gambar buah sawit matang dan 171 gambar buah sawit mentah. Sebanyak 80% data digunakan sebagai data latih, sementara 20% sisanya dialokasikan sebagai data uji. Dengan pembagian ini, data latih terdiri dari 354 gambar buah matang dan 137 gambar buah mentah. Sementara itu, data uji terdiri dari 88

gambar buah matang dan 34 gambar buah mentah. Proses pembagian data ini dirancang untuk memastikan bahwa model mendapatkan cukup data untuk belajar, sekaligus memungkinkan evaluasi yang objektif terhadap performa model. Hal ini dilakukan untuk memenuhi tujuan yaitu meminimalkan bias pada hasil pengujian.

Artitektur Model

Xception adalah arsitektur deep learning yang dikembangkan dari Inception, dengan peningkatan pada efisiensi dan kompleksitas. Nama "Xception" berarti "Extreme Inception," mencerminkan penerapan prinsip Inception secara lebih ekstrem. Xception dirancang untuk menangkap hubungan spasial dalam data dengan cara yang lebih efektif, memungkinkan pengolahan citra yang lebih mendetail dan presisi. Arsitektur ini telah terbukti sangat kuat dalam berbagai aplikasi deep learning, termasuk klasifikasi gambar, deteksi objek, dan segmentasi citra, menjadikannya salah satu pilihan utama dalam pengembangan model berbasis convolutional neural networks (CNN). Arsitektur ini memiliki 36 layer convolutional yang dikelompokkan dalam 14 modul, dengan residual connections pada semua modul kecuali yang pertama dan terakhir. Xception mengandalkan tiga aliran utama: entry flow, middle flow (diulang 8 kali), dan exit flow. Input standarnya adalah gambar dengan dimensi 299x299 piksel, menggunakan depthwise separable convolution untuk meningkatkan efisiensi dengan memisahkan operasi cross-channel dan spasial.

Dalam pelatihan, Xception sering memanfaatkan transfer learning dengan bobot pra-pelatihan dari ImageNet, yang dapat disesuaikan untuk tugas spesifik. Batch normalization dan fungsi aktivasi ReLU diterapkan setelah setiap layer convolution. Optimizer Adam dengan learning rate sekitar 0.001 digunakan untuk mengoptimalkan proses pelatihan. Evaluasi model dilakukan menggunakan metrik seperti akurasi, precision, recall, dan F1-score, dengan visualisasi melalui confusion matrix dan kurva loss. Keunggulan Xception terletak pada efisiensi komputasi dan akurasi tinggi dalam menangani dataset besar. Namun, implementasi Xception membutuhkan sumber daya komputasi yang memadai dan preprocessing data yang baik untuk mencapai hasil optimal. Gambar 3 merupakan *workflow Xception*.



Gambar 3. *Workflow Xception*

Sumber: Data Diolah

Penggunaan CUDA

Dalam penelitian ini, pemanfaatan CUDA (*Compute Unified Device Architecture*) menjadi elemen krusial untuk mempercepat proses pelatihan model CNN Xception. CUDA memungkinkan eksekusi komputasi paralel pada GPU, yang secara signifikan mempercepat pengolahan data, khususnya dalam melibatkan operasi berat seperti konvolusi dan manipulasi matriks besar.

Implementasi CUDA meliputi:

- a. Pemrosesan Paralel: CUDA memanfaatkan banyak core GPU untuk melakukan komputasi paralel, memungkinkan pemrosesan batch data gambar secara simultan.
- b. Optimasi Memori: Data yang digunakan dalam pelatihan, seperti bobot model dan hasil lapisan intermediate, disimpan dalam memori GPU untuk mengurangi latensi transfer data antara CPU dan GPU.
- c. Library Pendukung: Proses ini mengandalkan library seperti cuDNN untuk mempercepat operasi deep learning dan memaksimalkan efisiensi komputasi.
- d. Platform: Pelatihan dilakukan menggunakan Google Colab, yang menyediakan akses GPU berbasis CUDA, memanfaatkan TensorFlow sebagai framework utama untuk membangun dan melatih model.

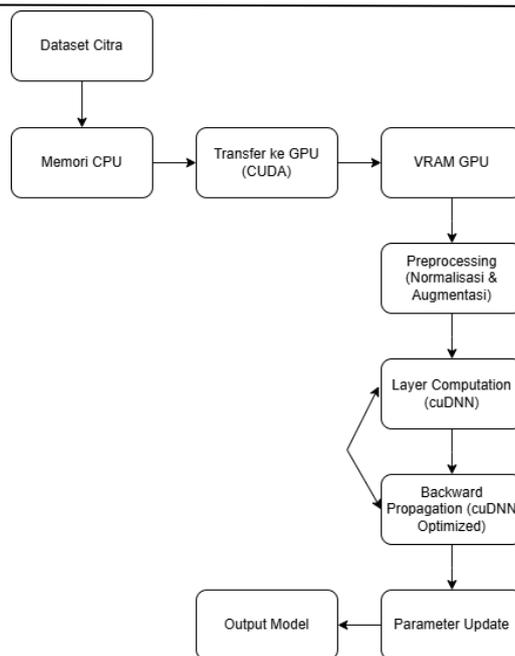
Dengan memanfaatkan CUDA, waktu pelatihan model Xception yang memerlukan komputasi tinggi dapat dikurangi secara signifikan, memungkinkan iterasi model yang lebih cepat dan efisien. Penggunaan ini sangat penting dalam memproses dataset besar yang diperkaya melalui augmentasi data. Workflow CUDA terdapat pada Gambar 4.

Evaluasi Model

Hyperparameter memegang peran penting dalam pelatihan model deep learning, khususnya untuk arsitektur Xception yang digunakan dalam klasifikasi kematangan buah sawit. Penelitian ini menggunakan optimizer Adam dengan learning rate 0.0001 untuk mencegah pembaruan bobot yang terlalu besar dan menghindari overshooting pada minimum loss. Adam menggabungkan keunggulan dari AdaGrad dan RMSProp, menyesuaikan learning rate secara dinamis berdasarkan momentum dan rata-rata kuadrat gradien. Parameter momentum, β_1 (0.9) dan β_2 (0.999), membantu model mengatasi noise pada dataset kompleks tanpa perlu disesuaikan lebih lanjut. Dengan optimizer Adam dan teknik augmentasi data seperti rescaling, model dapat belajar lebih efisien, menangkap variasi pola visual, dan meningkatkan performa klasifikasi.

Histogram

Histogram digunakan sebagai salah satu alat untuk mengevaluasi performa model machine learning yang telah dilatih. Evaluasi ini dilakukan dengan memvisualisasikan metrik seperti akurasi (*accuracy*) dan fungsi kerugian (*loss*) selama proses pelatihan dan validasi. Akurasi mencerminkan seberapa baik model memprediksi data secara benar, baik pada data latih maupun data validasi, sedangkan loss menggambarkan seberapa jauh prediksi model menyimpang dari nilai sebenarnya. Dengan menggunakan histogram atau grafik, kita dapat melihat pola perubahan nilai akurasi dan loss pada setiap epoch (iterasi pelatihan), sehingga membantu dalam memahami seberapa efektif model dalam belajar dari data.



Gambar 4. *Workflow CUDA*

Sumber: Data Diolah

Pengujian

Pengujian dilakukan dengan menguji performa model menggunakan gambar-gambar yang telah disiapkan sebelumnya sebagai data uji. Proses ini bertujuan untuk mengevaluasi seberapa baik model mampu mengenali pola dan melakukan prediksi terhadap data baru yang belum pernah dilihat selama tahap pelatihan. Dengan menggunakan gambar yang sudah ada, hasil pengujian dapat memberikan gambaran mengenai tingkat akurasi model serta kemampuannya dalam menggeneralisasi data. Selain itu, pengujian ini juga membantu mengidentifikasi potensi kelemahan atau kekurangan model dalam mengenali objek atau fitur tertentu dari gambar, sehingga langkah perbaikan dapat direncanakan jika diperlukan.

HASIL DAN PEMBAHASAN

Pengumpulan Data

Dalam penelitian ini, kami menggunakan dataset yang diunduh dari platform Kaggle, sebuah repositori online yang menyediakan berbagai dataset publik untuk keperluan penelitian dan pengembangan model machine learning. Dataset yang digunakan berisi gambar buah kelapa sawit yang diambil menggunakan kamera ponsel, mencakup kondisi buah sawit yang masih berada di pohon maupun yang telah dipanen. Data ini dikelompokkan ke dalam dua kategori utama, yaitu buah sawit matang dan buah sawit mentah. Dengan memanfaatkan dataset dari Kaggle, penelitian ini mendapatkan data awal yang representatif untuk proses pelatihan dan pengujian model deep learning, serta menjadi dasar bagi implementasi metode augmentasi untuk memperbanyak dan menyeimbangkan dataset agar tidak terjadi ketimpangan data, antara data buah sawit matang dan data buah sawit mentah.

Pembagian Data

Dataset yang digunakan dalam penelitian ini terdiri dari citra buah kelapa sawit yang dikelompokkan ke dalam dua kategori utama, yaitu buah sawit matang dan buah sawit mentah. Dataset tersebut kemudian dibagi menjadi dua bagian, yaitu data train dan data test, untuk memastikan proses pelatihan dan pengujian model yang terstruktur dan representatif. Pada data train, digunakan sebanyak 442 gambar untuk kategori buah sawit matang dan 171 gambar untuk kategori buah sawit mentah. Data train ini berfungsi sebagai bahan utama untuk melatih model deep learning agar mampu mengenali pola visual dari masing-masing kategori. Sementara itu, data test yang digunakan untuk mengevaluasi performa model terdiri dari 97 gambar untuk kategori buah sawit matang dan 49 gambar untuk kategori buah sawit mentah. Pembagian ini dilakukan untuk menjaga proporsi antara kedua kategori, sehingga model dapat dievaluasi secara adil dalam mengenali citra sawit matang dan mentah. Dengan pembagian data ini, diharapkan model yang dilatih memiliki kemampuan generalisasi yang baik, sehingga dapat mengklasifikasikan buah sawit dengan akurasi tinggi pada data baru.

Augmentasi

Proses augmentasi data berhasil memperbanyak dataset citra sawit, khususnya pada kategori buah sawit mentah yang sebelumnya memiliki jumlah data lebih sedikit dibandingkan dengan buah sawit matang. Dengan menerapkan berbagai teknik augmentasi, seperti flip vertikal dan horizontal, *gaussian blur*, *brightness adjustment*, *contrast adjustment*, *zooming*, serta, injeksi noise, jumlah data sawit mentah meningkat secara signifikan dari 97 menjadi 528 gambar. Hal ini membuat distribusi dataset menjadi lebih seimbang antara kategori buah matang dan mentah. Proses augmentasi dilakukan secara otomatis menggunakan Google Colab dengan memanfaatkan library *Augmentor* dan GPU, sehingga efisiensi pemrosesan data dapat terjaga. Dataset hasil augmentasi ini memberikan variasi yang lebih luas tanpa mengubah karakteristik utama citra, sehingga model deep learning dapat mengenali pola dengan lebih baik. Hasil pelatihan menunjukkan bahwa augmentasi data ini efektif dalam meningkatkan akurasi klasifikasi, mengurangi risiko *overfitting*, dan meningkatkan kemampuan generalisasi model dalam mengenali buah sawit matang maupun mentah pada berbagai kondisi. Proses augmentasi data ini menjadi salah satu tahapan penting dalam penelitian ini, karena memberikan kontribusi besar dalam meningkatkan performa model deep learning yang dikembangkan.

Implementasi Xception

Implementasi dari model Xception menggunakan library TensorFlow yang tersedia dalam Keras dengan bahasa pemrograman Python. Proses pengujian dijalankan pada platform Google Colab dengan memanfaatkan library Xception sebagai arsitektur model yang digunakan. Pengujian ini menggunakan learning rate 0,0001. Gambar 5 merupakan implementasi Xception.

```
# Load model Xception tanpa top layer (tanpa fully connected layers)
base_model = Xception(weights='imagenet', include_top=False, input_shape=(299, 299, 3))
```

Gambar 5. Workflow CUDA

Sumber: Data Diolah

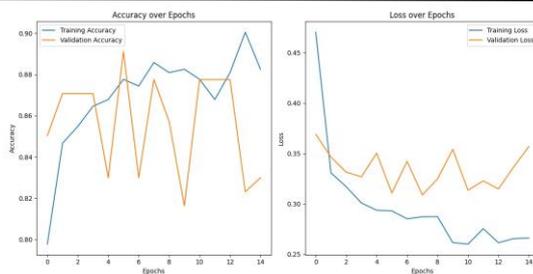
Hypermater ADAM

Implementasi hyperparameter Adam digunakan untuk mengoptimalkan proses pembelajaran model dengan memanfaatkan algoritma optimasi yang adaptif dan efisien. Adam, atau Adaptive Moment Estimation, merupakan salah satu metode optimasi yang sering digunakan dalam pelatihan model machine learning dan deep learning. Optimizer ini menggabungkan keunggulan dari metode Momentum dan RMSProp, sehingga mampu menyesuaikan laju pembelajaran (learning rate) secara adaptif berdasarkan momen pertama (rata-rata gradien) dan momen kedua (rata-rata kuadrat gradien) dari fungsi loss. Dalam implementasi ini, hyperparameter Adam digunakan dengan learning rate sebesar 0,0001. Nilai learning rate yang kecil dipilih untuk memastikan bahwa proses pembaruan bobot model berjalan secara bertahap dan stabil, sehingga dapat menghindari overshooting atau perubahan nilai bobot yang terlalu besar yang bisa membuat model gagal berkonvergensi. Dengan menggunakan learning rate 0,0001, proses pelatihan menjadi lebih presisi, terutama ketika model sedang mempelajari pola-pola kompleks dari dataset.

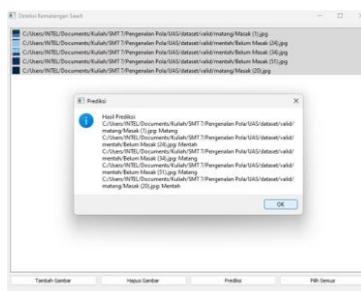
Pembahasan

Pada hasil percobaan yang dilakukan selama 15 epoch, diperoleh nilai akurasi dan loss sebagai hasil evaluasi performa model. Akurasi yang dihasilkan mencerminkan sejauh mana model mampu melakukan prediksi dengan benar terhadap data yang diberikan, baik pada tahap pelatihan maupun validasi. Nilai loss, di sisi lain, mengindikasikan seberapa besar tingkat kesalahan atau deviasi antara prediksi model dengan nilai target sebenarnya. Setelah melalui proses pelatihan selama 15 epoch, model berhasil mencapai akurasi sebesar 90% dan loss sebesar 27%. Sedangkan untuk akurasi untuk validasi yaitu sebesar 83% dan loss sebesar 35%. Nilai akurasi ini menunjukkan bahwa model telah mampu mempelajari pola dalam dataset dengan baik, sedangkan nilai loss yang diperoleh memberikan gambaran tentang tingkat kesalahan prediksi model yang semakin menurun seiring bertambahnya epoch. Histogramnya tercantum pada Gambar 6.

Setelah model selesai dibuat dan dilatih menggunakan data train dan validation, langkah selanjutnya yang sangat penting adalah melakukan pengujian menggunakan data yang belum pernah dilihat oleh model sebelumnya, yaitu data uji atau test data. Pengujian ini bertujuan untuk mengukur seberapa baik model yang telah dilatih dalam menggeneralisasi pola dan fitur yang ada dalam data yang tidak terlibat selama pelatihan. Dengan menggunakan data uji, kita bisa mengevaluasi kinerja model dalam kondisi yang lebih nyata dan menilai apakah model benar-benar efektif untuk digunakan pada data yang belum dikenali sebelumnya. Untuk mempermudah interaksi dan pemahaman hasil pengujian, pengujian model ini dapat dilakukan dengan membuat tampilan Graphical User Interface (GUI). Dengan adanya GUI, pengguna dapat lebih mudah mengakses dan melihat hasil evaluasi model secara langsung. GUI ini dapat menampilkan berbagai hasil, seperti akurasi model, loss yang tercatat, dan mungkin juga visualisasi lain seperti confusion matrix, yang memberikan gambaran tentang bagaimana model mengklasifikasikan data dengan benar atau salah. Pengujian pada penelitian ini ada pada gambar 6.



Gambar 6. Histogram akurasi dan *loss*
Sumber: Data Diolah



Gambar 7. Pengujian dengan GUI
Sumber: Data Diolah

SIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi tingkat kematangan buah kelapa sawit menggunakan metode Deep Learning dengan arsitektur Xception dan teknik augmentasi data. Dengan memanfaatkan dataset yang terdiri dari 613 citra, penelitian ini menunjukkan bahwa penerapan augmentasi data secara signifikan meningkatkan jumlah dan variasi data, khususnya pada kategori buah sawit yang belum matang, sehingga mengatasi masalah ketidakseimbangan kelas. Hasil pelatihan model menunjukkan akurasi mencapai 90% dengan nilai *loss* yang menurun, yang mengindikasikan bahwa model mampu mengenali pola visual dengan baik. Implementasi arsitektur Xception, yang mengandalkan *depthwise separable convolution*, terbukti efektif dalam meningkatkan efisiensi komputasi dan akurasi klasifikasi. Penggunaan optimizer Adam dengan learning rate yang tepat juga berkontribusi pada stabilitas dan kecepatan konvergensi model. Selain itu, pemanfaatan CUDA dalam proses pelatihan mempercepat eksekusi komputasi, memungkinkan penelitian ini untuk menangani dataset yang lebih besar dan kompleks. Studi ini memberikan kontribusi penting dalam pengembangan sistem klasifikasi otomatis berbasis citra, yang dapat meningkatkan efisiensi dan kualitas produksi CPO di industri kelapa sawit. Dengan hasil yang diperoleh, diharapkan model ini dapat diimplementasikan dalam praktik industri untuk membantu pekerja dalam mengidentifikasi kematangan buah kelapa sawit secara lebih konsisten dan akurat. Penelitian ini juga membuka peluang untuk penelitian lanjutan dalam pengembangan teknologi klasifikasi berbasis citra di sektor pertanian dan perkebunan lainnya. Secara keseluruhan, penelitian ini menunjukkan potensi besar dari penerapan teknologi Deep Learning dalam meningkatkan produktivitas dan kualitas hasil pertanian, serta memberikan dasar yang kuat untuk pengembangan sistem klasifikasi otomatis yang lebih canggih di masa depan.

DAFTAR PUSTAKA

- Akbar, A. R. M., Wibowo, A. D., & Santoso, R. (2023). Investigation On The Optimal Harvesting Time Of Oil Palm Fruit. *Jurnal Teknik Pertanian Lampung*, 12(2), doi:10.23960/jtep-l.v12i2.524-532
- Avery, D.K. (2014). Fatigue Behavior Of Stainless Steel Sheet Specimens At Extremely High Temperatures. *SAE INTERNATIONAL*, 7(3), 560–566, doi:10.4271/2014-01-0975.
- Carnegie, J. O., Prabowo, A. R., Budiana, E. P., & Singgih, I. (2022). Essential Oil Plants Image Classification Using Xception Model. *Procedia Comput Sci*, 204.
- Fevriera, S., & Devi, F. S. (2023). Analisis Produksi Kelapa Sawit Indonesia: Pendekatan Mikro Dan Makro Ekonomi. *TRANSFORMATIF: Jurnal Ekonomi Bisnis dan Kewirausahaan*, 12(1), 1–16.
- Khasanah, C. U., Pertiwi, A. K., & Witamajaya, F. (2023). Implementasi Data Augmentation Random Erasing Dan Gridmask Pada CNN Untuk Klasifikasi Batik. *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (SISFOTENIKA)*, 13(1), 16–28.
- Murgianto, F., Edyson, Ardiyanto, A., Putra, S. K., & Prabowo, L. (2021). Potensi Kandungan Minyak Kelapa Sawit dengan Berbagai Tingkat Berondolan Lepas di Piringan. *Jurnal Agro Industri Perkebunan*, 9(2), 91–98, doi: 10.25181/jaip.v9i2.2161.
- Masaugi, F. (2024). Deep Learning Menggunakan Algoritma Xception Dan Augmentasi Flip Pada Klasifikasi Kematangan Sawit. *KLIK Kajian Ilmiah Informatika dan Komputasi*, 6(4), 2918–2927, doi: 10.30865/klik.v4i6.1938.
- Rizki, F., Putra, M. P. K., Assuja, M. A., & Ariany, F. (2023). Implementasi Deep Learning Dengan Augmentasi Data Pada Identifikasi Anggrek. *Jurnal Informatika dan Rekayasa Perangkat Lunak*, 4(3), 357–366, 2023, doi: 10.33365/jatika.v4i3.3652.
- Statistik, B. P. (2024). Statistik Kelapa Sawit Indonesia 2023. *INDONESIAN OIL PALM STATISTICS*, 17.
- Siswanto, Y., Lubis, Z., & Akoeb, E. (2020). Analisis Faktor-Faktor Yang Mempengaruhi Produksi Kelapa Sawit Rakyat Di Desa Tebing Linggahara Kecamatan Bilah Barat Kabupaten Labuhanbatu. *AGRISAINS Jurnal Ilmiah Magister Agribisnis*, 2(1), 60–70, doi: 10.31289/agrisains.v2i1.255.